



(21) 申请号 202411298458.X

(22) 申请日 2024.09.18

(65) 同一申请的已公布的文献号

申请公布号 CN 119762417 A

(43) 申请公布日 2025.04.04

(73) 专利权人 香港理工大学

地址 中国香港九龙红磡育才道11号

(72) 发明人 杨波 张子辉 宋宏康

(74) 专利代理机构 深圳中一联合知识产权代理

有限公司 44414

专利代理师 张禹

(51) Int. Cl.

G06T 7/00 (2017.01)

G06T 7/10 (2017.01)

(56) 对比文件

CN 115496771 A, 2022.12.20

CN 114782472 A, 2022.07.22

审查员 周锦


权利要求书2页 说明书17页 附图5页

(54) 发明名称

基于边界感知的三维MRI肿瘤分割方法及肿瘤诊断设备

(57) 摘要

本申请提供了一种基于边界感知的三维MRI肿瘤分割方法及肿瘤诊断设备。该方法包括：获取多位肿瘤病患的三维MRI作为肿瘤数据集，三维MRI包括钆增强的T1SC切片；将肿瘤数据集中的三维MRI作为第一分割模型的输入进行肿瘤分割，得到三维MRI中肿瘤的分类标签；其中，第一分割模型为基于卷积神经网络CNN的模型，第一分割模型中包括第一模型分支和第二模型分支，第一模型分支用于预测分类标签，第二模型分支用于基于边界感知预测肿瘤的表面距离场，表面距离场用于描述三维MRI中每个体素到肿瘤表面的最近距离，第一分割模型的训练和优化基于第一模型分支和第二模型分支的训练和优化进行。



1. 一种基于边界感知的三维磁共振成像MRI肿瘤分割方法,其特征在于,包括:

获取多位肿瘤病患的三维MRI作为肿瘤数据集,所述三维MRI包括钆增强的纵向弛豫时间加权矢状位图像T1SC切片;

将所述肿瘤数据集中的所述三维MRI作为第一分割模型的输入进行肿瘤分割,得到所述三维MRI中肿瘤的分类标签;

其中,所述第一分割模型为基于卷积神经网络CNN的模型,所述第一分割模型中包括第一模型分支和第二模型分支,所述第一模型分支用于预测所述分类标签,所述第二模型分支用于基于边界感知预测肿瘤的表面距离场,所述表面距离场用于描述所述三维MRI中每个体素到所述肿瘤表面的最近距离,第一分割模型的训练和优化基于所述第一模型分支和所述第二模型分支的训练和优化进行。

2. 根据权利要求1所述的方法,其特征在于,所述第二模型分支基于第一边界感知损失函数训练和优化,所述第一边界感知损失函数用于确定所述三维MRI中每个体素的边界感知损失,所述每个体素的边界感知损失基于所述每个体素的表面距离值确定,所述表面距离值用于表示所述每个体素到肿瘤表面的最近距离。

3. 根据权利要求2所述的方法,其特征在于,所述体素包括所述肿瘤外部的体素和所述肿瘤内部的体素,所述肿瘤外部的体素的所述表面距离值表示为负值,所述肿瘤内部的体素的所述表面距离值表示为正值。

4. 根据权利要求3所述的方法,其特征在于,若所述肿瘤外部的体素的表面距离值的绝对值大于所述肿瘤内部的体素的最大表面距离值,则所述表面距离值计为0。

5. 根据权利要求4所述的方法,其特征在于,所述每个体素的边界感知损失基于所述每个体素的所述表面距离值归一化后的值确定。

6. 根据权利要求5所述的方法,其特征在于,所述第二模型分支的训练和优化按照所述肿瘤的分类进行。

7. 根据权利要求6所述的方法,其特征在于,所述第一边界感知损失函数表示为下式:

$$\ell_{ba} = -\left(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}\right)^2 * |f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}|,$$

其中,所述 ℓ_{ba} 用于表示所述边界感知损失,所述h用于表示所述三维MRI的横向像素点数,所述w用于表示三维MRI的纵向像素点数,所述d用于表示所述三维MRI的切片数量,所述k用于表示所述三维MRI的类别总数,所述 $f_{(h,w,d,k)}$ 用于表示所述第二模型分支预测的第(h,w,d,k)个体素的表面距离值,所述 $\bar{f}_{(h,w,d,k)}$ 用于表示第(h,w,d,k)个体素的真实表面距离值。

8. 根据权利要求7所述的方法,其特征在于,所述第二模型分支基于所述三维MRI中的所有体素的所述边界感知损失的平均值训练和优化。

9. 根据权利要求8所述的方法,其特征在于,所述第一模型分支基于第一分割损失函数训练和优化,所述第一分割损失函数包括交叉熵损失函数和骰子损失函数。

10. 一种肿瘤诊断设备,其特征在于,包括:

获取模块,用于获取多位肿瘤病患的三维磁共振成像MRI作为肿瘤数据集,所述三维MRI包括钆增强的纵向弛豫时间加权矢状位图像T1SC切片;

分割模块,用于将所述肿瘤数据集中的所述三维MRI作为第一分割模型的输入进行肿

瘤分割,得到所述三维MRI中肿瘤的分类标签;

其中,所述第一分割模型为基于卷积神经网络CNN的模型,所述第一分割模型中包括第一模型分支和第二模型分支,所述第一模型分支用于预测所述类别标签,所述第二模型分支用于基于边界感知预测肿瘤的表面距离场,所述表面距离场用于描述所述三维MRI中每个体素到所述肿瘤表面的最近距离,所述第一分割模型的训练和优化基于所述第一模型分支和所述第二模型分支的训练和优化进行。

基于边界感知的三维MRI肿瘤分割方法及肿瘤诊断设备

技术领域

[0001] 本申请涉及图像分割技术领域,尤其涉及一种基于边界感知的三维MRI肿瘤分割方法及肿瘤诊断设备。

背景技术

[0002] 肿瘤精确的形态定量,包括肿瘤的大小、位置和类型,有望增强监测方案和优化治疗计划策略。在过去的几年中,已经提出了一系列基于卷积、注意力和大型模型的复杂肿瘤分割方法。这些方法在各种医学图像上表现出色,这要归功于大规模数据集的可用性。然而,这些方法在分割某些肿瘤(例如脊髓肿瘤)时仍然存在很大的挑战,存在准确较低的问题。因此,对于这些肿瘤而言,仍然缺乏能够精确分割和识别肿瘤的自动模型。

发明内容

[0003] 本申请实施例提供了一种基于边界感知的三维MRI肿瘤分割方法及肿瘤诊断设备。

[0004] 第一方面,本申请实施例提供了一种基于边界感知的三维MRI肿瘤分割方法,该方法包括:

[0005] 获取多位肿瘤病患的三维MRI作为肿瘤数据集,三维MRI包括钆增强的T1SC切片;

[0006] 将肿瘤数据集中的三维MRI作为第一分割模型的输入进行肿瘤分割,得到三维MRI中肿瘤的分类标签;

[0007] 其中,第一分割模型为基于卷积神经网络CNN的模型,第一分割模型中包括第一模型分支和第二模型分支,第一模型分支用于预测类别标签,第二模型分支用于基于边界感知预测肿瘤的表面距离场,表面距离场用于描述三维MRI中每个体素到肿瘤表面的最近距离,第一分割模型的训练和优化基于第一模型分支和第二模型分支的训练和优化进行。

[0008] 可选的,第二模型分支基于第一边界感知损失函数训练和优化,第一边界感知损失函数用于确定三维MRI中每个体素的边界感知损失,每个体素的边界感知损失基于每个体素的表面距离值确定,表面距离值用于表示每个体素到肿瘤表面的最近距离。

[0009] 可选的,体素包括肿瘤外部的体素和肿瘤内部的体素,肿瘤外部的体素的表面距离值表示为负值,肿瘤内部的体素的表面距离值表示为正值。

[0010] 可选的,若肿瘤外部的体素的表面距离值的绝对值大于肿瘤内部的体素的最大表面距离值,则表面距离值计为0。

[0011] 可选的,每个体素的边界感知损失基于每个体素的表面距离值归一化后的值确定。

[0012] 可选的,第二模型分支的训练和优化按照肿瘤的分类进行。

[0013] 可选的,第一边界感知损失函数表示为下式:

$$[0014] \quad \ell_{ba} = -\left(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}\right)^2 * \left|f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}\right|,$$

[0015] 其中, ℓ_{ba} 用于表示边界感知损失,h用于表示三维MRI的横向像素点数,w用于表示

三维MRI的纵向像素点数,d用于表示三维MRI的切片数量,k用于表示三维MRI的类别总数, $f_{(h,w,d,k)}$ 用于表示第二模型分支预测的第(h,w,d,k)个体素的表面距离值, $\bar{f}_{(h,w,d,k)}$ 用于表示第(h,w,d,k)个体素的真实表面距离值。

[0016] 可选的,第二模型分支基于三维MRI中的所有体素的边界感知损失的平均值训练和优化。

[0017] 可选的,第一模型分支基于第一分割损失函数训练和优化,第一分割损失函数包括交叉熵损失函数和骰子损失函数。

[0018] 第二方面,本申请实施例提供了一种肿瘤诊断设备,包括:

[0019] 获取模块,用于获取多位肿瘤病患的三维MRI作为肿瘤数据集,三维MRI包括钆增强的T1SC切片;

[0020] 分割模块,用于将肿瘤数据集中的三维MRI作为第一分割模型的输入进行肿瘤分割,得到三维MRI中肿瘤的分类标签;

[0021] 其中,第一分割模型为基于卷积神经网络CNN的模型,第一分割模型中包括第一模型分支和第二模型分支,第一模型分支用于预测类别标签,第二模型分支用于基于边界感知预测肿瘤的表面距离场,表面距离场用于描述三维MRI中每个体素到肿瘤表面的最近距离,第一分割模型的训练和优化基于第一模型分支和第二模型分支的训练和优化进行。

[0022] 可选的,第二模型分支基于第一边界感知损失函数训练和优化,第一边界感知损失函数用于确定三维MRI中每个体素的边界感知损失,每个体素的边界感知损失基于每个体素的表面距离值确定,表面距离值用于表示每个体素到肿瘤表面的最近距离。

[0023] 可选的,体素包括肿瘤外部的体素和肿瘤内部的体素,肿瘤外部的体素的表面距离值表示为负值,肿瘤内部的体素的表面距离值表示为正值。

[0024] 可选的,若肿瘤外部的体素的表面距离值的绝对值大于肿瘤内部的体素的表面距离值,则表面距离值计为0。

[0025] 可选的,每个体素的边界感知损失基于每个体素的表面距离值归一化后的值确定。

[0026] 可选的,第二模型分支的训练和优化按照肿瘤的分类进行。

[0027] 可选的,第一边界感知损失函数表示为下式:

$$[0028] \quad \ell_{ba} = -\left(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}\right)^2 * \left|f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}\right|,$$

[0029] 其中, l_{ba} 用于表示边界感知损失,h用于表示三维MRI的横向像素点数,w用于表示三维MRI的纵向像素点数,d用于表示三维MRI的切片数量,k用于表示三维MRI的类别总数, $f_{(h,w,d,k)}$ 用于表示第二模型分支预测的第(h,w,d,k)个体素的表面距离值, $\bar{f}_{(h,w,d,k)}$ 用于表示第(h,w,d,k)个体素的真实表面距离值。

[0030] 可选的,第二模型分支基于三维MRI中的所有体素的边界感知损失的平均值训练和优化。

[0031] 可选的,第一模型分支基于第一分割损失函数训练和优化,第一分割损失函数包括交叉熵损失函数和骰子损失函数。

[0032] 第三方面,本申请实施例提供了一种电子设备,包括存储器、至少一个处理器以及

存储在存储器中并可在处理器上运行的计算机程序,处理器执行计算机程序时实现如上述第一方面中任一项所述的方法。

[0033] 第四方面,本申请实施例提供了一种计算机可读存储介质,所述计算机可读存储介质存储有计算机程序,所述计算机程序被处理器执行时实现如上述第一方面中任一项所述的方法。

[0034] 第五方面,本申请实施例提供了一种计算机程序产品,当计算机程序产品在电子设备上运行时,使得电子设备执行上述第一方面中任一项所述的方法。

[0035] 本申请中,第一分割模型对三维MRI中肿瘤的分割可以分为第一模型分支对肿瘤类别的预测,和第二模型分支基于边界感知对肿瘤表面距离场的预测。基于第二模型分支可以感知三维MRI中肿瘤的三维表面,从而捕捉肿瘤边界和周围区域的细节,有助于提高肿瘤分割的准确性。

附图说明

[0036] 为了更清楚地说明本申请实施例中的技术方案,下面将对实施例描述中所需要使用的附图作简单地介绍。

[0037] 图1是本申请实施例提供的不同肿瘤/器官的MRI示意图。

[0038] 图2是本申请实施例提供的基于边界感知的三维MRI肿瘤分割方法的流程示意图。

[0039] 图3是本申请一实施例提供的第一分割模型的结构示意图。

[0040] 图4是本申请另一实施例提供的第一分割模型的结构示意图。

[0041] 图5是本申请实施例提供的肿瘤表面距离场的示例图。

[0042] 图6是本申请实施例提供的两阶段训练基线的结构示意图。

[0043] 图7A-图7D是本申请一实施例提供的肿瘤诊断实验的结果示意图。

[0044] 图8是本申请另一实施例提供的肿瘤诊断实验的结果示意图。

[0045] 图9是本申请实施例提供的肿瘤诊断设备的结构示意图。

[0046] 图10是本申请实施例提供的电子设备的结构示意图。

具体实施方式

[0047] 下面将结合本发明实施例中的附图,对本发明实施例的技术方案进行描述。

[0048] 肿瘤精确的形态定量,包括肿瘤的大小、位置和类型,有望增强监测方案和优化治疗计划策略。在过去的几年中,已经提出了一系列基于卷积、注意力和大型模型的复杂肿瘤分割方法。这些方法在各种医学图像上表现出色,这要归功于大规模数据集的可用性。然而,这些方法在分割某些肿瘤(例如脊髓肿瘤)时仍然存在很大的挑战,存在准确较低的问题。因此,对于这些肿瘤而言,仍然缺乏能够精确分割和识别肿瘤的自动模型。

[0049] 以脊髓肿瘤为例,脊髓肿瘤是导致神经系统发病率和死亡率的重要因素。脊髓是中枢神经系统的关键组成部分,对躯体感觉和运动功能至关重要。常见的脊髓肿瘤类型包括星形细胞瘤、室管膜瘤、血管母细胞瘤和脊膜瘤。脊髓肿瘤主要通过三维磁共振成像(magnetic resonance imaging, MRI)扫描来识别。在临床领域,区分不同类型的脊髓肿瘤仍然是一项艰巨的挑战,从而可能导致误诊、肿瘤生长监测失败以及随后的治疗干预延迟。

[0050] 脊髓肿瘤难以通过上述分割方法进行准确分割的主要原因在于,脊髓肿瘤往往具

有微小的尺寸、不同的位置和形状。然而上述分割方法主要侧重于辨别具有相对较大形态的形状,例如脑肿瘤、左/右心室、腹部器官等,而忽略了脊髓肿瘤识别这一具有挑战性的问题。如图1所示,位于长圆柱形脊髓中的常见脊髓肿瘤往往具有微小的尺寸、不同的位置和形状变化,而其他肿瘤/器官则表现出相对均匀和较大的尺寸。这意味着,由于脊髓肿瘤与其他身体器官/肿瘤之间存在明显的解剖差异,将上述分割方法简单应用于脊髓肿瘤分割会导致准确性较低。

[0051] 基于此,图2所示为本申请实施例提供了一种基于边界感知的三维MRI肿瘤分割方法,该方法包括步骤S210-S220。

[0052] 在步骤S210,获取多位肿瘤病患的三维MRI作为肿瘤数据集,三维MRI可以包括钆增强的纵向弛豫时间加权矢状位图像T1SC切片。肿瘤病患的肿瘤类型不作限定,例如可以是脊髓肿瘤。三维MRI中T1SC切片的分辨率、厚度、数量均不作限定,基于T1SC切片可以还原肿瘤病患的病患区域以及肿瘤的三维形貌。值得注意的是,可以对肿瘤数据集中的T1SC切片进行预处理。例如,对T1SC切片进行缩放、扫描强度归一化等。

[0053] 在步骤S220,将肿瘤数据集中的三维MRI作为第一分割模型的输入进行肿瘤分割,得到三维MRI中肿瘤的分类标签。

[0054] 其中,第一分割模型可以为基于卷积神经网络(convolutional neural networks,CNN)的模型。随着卷积神经网络的流行,早期的方法主要采用基于CNN的框架进行医学图像分割,包括U-Net、3D-UNet、Y-Net、KiU-Net、U-Net++、U-Net 3+、nnUNet,以及许多其他变体。其中,nnUNet是一个通用的分割框架,可以自动配置网络框架和设置以提取多个尺度的特征,在各种医疗数据集上表现出特别强大的性能。作为一个示例,第一分割模型可以选择nnUNet作为骨干网络。

[0055] 第一分割模型中可以包括第一模型分支和第二模型分支,第一模型分支可以用于预测类别标签,第二模型分支可以用于基于边界感知预测肿瘤的表面距离场,表面距离场用于描述三维MRI中每个体素到肿瘤表面的最近距离。例如,第一模型分支和第二模型分支可以分别是第一分割模型中的一个卷积神经层。

[0056] 为了提高二维自然图像的分割性能,先前的研究将边界信息集成到学习过程中。然而,它们主要关注仅回归边缘像素,而忽略了形状表面更广泛背景的细节。最近的一些研究利用有符号距离进行医学图像分割。然而,它们要么专注于简单的二维情况,要么需要复杂的变形或变换过程。此外,它们也没有考虑到跨多类的边界变化。然而值得注意的是,本申请中的第二模型分支可以分别学习不同类别肿瘤的三维表面距离场。以脊髓肿瘤为例,第二模型分支可以分别学习四种脊髓肿瘤的三维表面距离场,从而有助于关注到跨多类的边界变化。

[0057] 第一分割模型的训练和优化可以基于第一模型分支和第二模型分支的训练和优化进行。例如,第一模型分支和第二模型分支可以分别基于相应的损失函数训练和优化。其中,第一模型分支的训练和优化可以参照肿瘤专家对肿瘤病患的三维MRI的手动肿瘤注释进行,第二模型分支的训练和优化可以参照三维MRI中每个体素到肿瘤表面的最近距离的测量值进行。

[0058] 作为一个示例,第一分割模型的架构可以如图3所示。其中骨干网络即第一分割模型,分割分支即第一模型分支,表面距离场分支即第二模型分支,分割分支和表面距离场分

支分别基于损失函数1和损失函数2训练和优化。

[0059] 本申请中,第一分割模型对三维MRI中肿瘤的分割可以分为第一模型分支对肿瘤类别的预测,和第二模型分支基于边界感知对肿瘤表面距离场的预测。基于第二模型分支可以感知三维MRI中肿瘤的三维表面,从而捕捉肿瘤边界和周围区域的细节,有助于提高肿瘤分割的准确性。

[0060] 可选的,第二模型分支可以基于第一边界感知损失函数训练和优化,第一边界感知损失函数可以用于确定三维MRI中每个体素的边界感知损失,每个体素的边界感知损失可以基于每个体素的表面距离值确定,表面距离值可以用于表示每个体素到肿瘤表面的最近距离。例如,对于每个体素而言,第二模型分支预测得到的该体素到肿瘤表面的最近距离,与实际测量得到的该体素肿瘤表面的最近距离之间的差异,可以用于确定其边界感知损失。也就是说,第一边界感知损失函数的求解可以基于该差异进行。基于第一边界感知损失函数,可以提高第二模型分支预测肿瘤的表面距离场的准确性,从而有助于对于肿瘤和周围区域的细节进行更精准的感知。

[0061] 可选的,三维MRI中的体素可以包括肿瘤外部的体素(也可以称为背景体素)和肿瘤内部的体素,肿瘤外部的体素的表面距离值可以表示为负值,肿瘤内部的体素的表面距离值可以表示为正值。也就是说,肿瘤表面(即肿瘤边界)即为表面距离值为0的分界。基于此,有助于区分肿瘤外部和内部的体素,从而准确确定肿瘤边界。

[0062] 可选的,若肿瘤外部的体素的表面距离值的绝对值大于肿瘤内部的体素的最大表面距离值,则该体素的表面距离值计为0。也就是说,当肿瘤外部的体素的表面距离值符合上述情况时,就将其截断为0。通常当肿瘤外部的体素的表面距离值的绝对值大于肿瘤内部的体素的最大表面距离值时,表明该体素距离肿瘤边界较远,属于背景体素。背景体素对于感知肿瘤边界的不再有较大意义,因此可以不计入肿瘤表面距离场。基于此,可以更加关注肿瘤边界周围体素,从而有助于更准确地确定肿瘤边界。

[0063] 可选的,每个体素的边界感知损失可以基于每个体素的表面距离值归一化后的值确定。作为一个示例,对每个体素的表面距离值的归一化可以基于三维MRI中所有体素的最大表面距离值进行。例如,每个体素的表面距离值归一化后的值=(表面距离值/最大表面距离值+1)/2。基于对表面距离值的归一化处理,可以提高边界感知损失的计算效率。

[0064] 可选的,第二模型分支的训练和优化可以按照肿瘤类别进行。基于前文所述,第二模型分支可以分别学习不同类别肿瘤的三维表面距离场,因此第二模型分支的训练和优化也可以按照肿瘤类别进行,从而有助于第二模型分支更准确地关注到跨多类的边界变化。

[0065] 可选的,第一边界感知损失函数可以表示为下式:

$$[0066] \quad \ell_{ba} = -\left(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}\right)^2 * |f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}| (1),$$

[0067] 其中, l_{ba} 可以用于表示边界感知损失,h可以用于表示三维MRI的横向像素点数,w可以用于表示三维MRI的纵向像素点数,d可以用于表示三维MRI的切片数量,k可以用于表示三维MRI的类别总数, $f_{(h,w,d,k)}$ 可以用于表示第二模型分支预测的第(h,w,d,k)个体素的表面距离值, $\bar{f}_{(h,w,d,k)}$ 可以用于表示第(h,w,d,k)个体素的真实表面距离值。

[0068] 值得注意的是,有了预测的肿瘤表面距离值和相应的真实表面距离值,一种简单

的方法是选择 $\ell_1 = f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}$ 作为损失函数来平等地优化每个体素。然而,由于脊髓肿瘤仅占据相对较小的区域,大多数表面距离值都是零,属于截断的背景体素。为了使边界感知损失真正关注肿瘤边界区域,在本申请中引入了 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$ 这一项。基于此,可以驱动模型更多地关注具有非零距离值的体素且属于感兴趣的边界区域的体素,从而有助于更准确地确定肿瘤的边界。

[0069] 可选的,第二模型分支可以基于三维MRI中的所有体素的边界感知损失的平均值训练和优化。即总的边界感知损失可以取所有体素的边界感知损失的平均值。

[0070] 可选的,第一模型分支基于第一分割损失函数训练和优化,第一分割损失函数包括交叉熵损失函数和骰子损失 (Dice Loss) 函数。例如,交叉熵损失函数可以基于式 (2) 确定。又如,Dice损失函数可以基于式 (3) 确定。

$$[0071] \quad \ell_{ce}(\mathcal{P}, \mathcal{G}) = - \sum_{i=1}^N \sum_{k=1}^K g_{i,k} \cdot \log(p_{i,k}) \quad (2),$$

$$[0072] \quad \ell_{dice}(\mathcal{P}, \mathcal{G}) = - \frac{1}{|K|} \sum_{k=1}^K \left(\frac{2 \sum_i p_{i,k} \cdot g_{i,k}}{\sum_i p_{i,k} + \sum_i g_{i,k}} \right) \quad (3),$$

[0073] 其中,其中, $\ell_{ce}(\mathcal{P}, \mathcal{G})$ 表示交叉熵损失函数, $\ell_{dice}(\mathcal{P}, \mathcal{G})$ 表示Dice Loss函数, \mathcal{P} 表示预测分割结果, \mathcal{G} 表示真实分割, $p_{i,k}$ 是网络的柔性最大传递函数输出,表示第 i 个体素被分类为 k 类的概率; g 为对应于真实分割图的一位有效编码, p 和 g 的维度均为 $N \times K$; $i \in N$, 表示给定补丁或批次中的体素数量; $k \in K$, 表示分割任务中的类别总数;根据真实分割, 仅当第 i 个体素确实属于 k 类时, $g_{i,k}$ 才设置为1; 否则 $g_{i,k}$ 设置为0。

[0074] 进一步地,第一分割模型可以与上述三个损失(总的边界感知损失、交叉熵损失、骰子损失)一起进行联合训练。例如式 (4) 所示,可以简单地使三个损失的权重相等来计算第一分割模型的总损失。

$$[0075] \quad 1 = 1_{ce} + 1_{dice} + 1_{ba} \quad (4)。$$

[0076] 下面结合附图,以脊髓肿瘤为例,对本申请实施例的基于边界感知的三维MRI肿瘤分割方法进行举例介绍。

[0077] 脊髓肿瘤数据集

[0078] 数据收集:脊髓肿瘤数据集中包含653名患者的三维MRI,收集时间为2017年10月至2023年9月,专门用于术前评估未经治疗干预的脊髓肿瘤。该数据集中包含了全面的脊椎表现(涵盖颈部、胸部和腰部区域),包括四种主要的脊髓肿瘤类型:1) 脊膜瘤(247名患者)、2) 室管膜瘤(203名患者)、3) 星形细胞瘤(101名患者)和4) 血管母细胞瘤(102患者),如图1第一行所示。

[0079] 每位患者的MRI均由钆增强T1 SC切片组成。如表1中所示,此数据集中矢状面磁共振扫描的原始分辨率各不相同,平面内分辨率范围为0.34至1.06毫米,切片厚度范围为1.5至8毫米。MRI在矢状面中的切片数量各不相同,范围从最少9个到最多36个。

[0080] 表1脊髓肿瘤数据集中磁共振扫描的详细信息

	脊膜瘤	室管膜瘤	星形细胞瘤	血管母细胞瘤
患者数量	247	203	101	102
肿瘤大小 (cm^3)	2.8 ± 2.4	4.9 ± 5.2	5.8 ± 6.0	2.5 ± 3.7
[0081] 面内分辨率 (mm)	0.601 ± 0.124	0.516 ± 0.128	0.579 ± 0.161	0.558 ± 0.155
切片厚度 (mm)	4.011 ± 0.547	3.766 ± 0.472	3.684 ± 0.475	3.625 ± 0.392
切片数量	11.0 ± 0.206	11.0 ± 0.438	11.4 ± 2.501	11.1 ± 0.421

[0082] 肿瘤注释:每位患者的MRI都附有专家精心策划的手动肿瘤注释。两名独立的神经放射学家在钆增强T1SC上手动标记真实肿瘤区域。如果肿瘤区域的划分存在争议,则最终决定权将交给资深神经放射学家,以确保数据注释的最高保真度和精确度。

[0083] 数据分区:为了进行更全面、更公平的比较,可以将脊髓肿瘤数据集均匀地划分为五个不同的部分,以便对各种方法和未来研究进行稳健的5折交叉评估(5-fold cross evaluation)。表2总结了这五部分的详细信息。

[0084] 表2五个部分中的受试者数量

	脊膜瘤	室管膜瘤	星形细胞瘤	血管母细胞瘤	共计
Fold 1	54	42	19	17	132
[0085] Fold 2	50	27	26	26	129
Fold 3	42	44	25	19	130
Fold 4	58	38	16	19	131
Fold 5	43	52	15	21	131

[0086] 数据预处理:遵循现有工作中广泛采用的标准化协议,矢状切片的分辨率在前后方向和上下方向均重新缩放为0.47毫米,在左右方向重新缩放为3.3毫米。磁共振扫描的强度值经过三线性插值,肿瘤注释通过最近邻插值。每个体积的强度通过首先从每个体素中减去平均强度值,然后除以扫描的标准差来归一化。

[0087] 分割模型

[0088] 如图4所示,给定一个输入三维磁共振扫描 $T \in \mathbb{R}^{H \times W \times D}$,其中 $H \times W$ 表示切片分辨率, D 表示切片数。将其输入到骨干网络即第一分割模型(例如nnUNet)中,获得每个体素的多类分割输出 $S \in \mathbb{R}^{H \times W \times D \times K}$,其中 K 表示类别总数。在本例中, K 设置为5,代表4种类型的脊髓肿瘤以及背景类别。令nnUNet中一个卷积神经层为分割分支(即第一模型分支),与分割分支并行,添加另一个分支(即第二模型分支)来预测肿瘤表面距离场 $F \in \mathbb{R}^{H \times W \times D \times K}$,其中应用了单个卷积神经层。分割分支使用广泛使用的交叉熵和Dice损失进行监督,并使用真实语义标签。表面距离场使用多类边界感知损失(即第一边界感知损失函数)进行监督,并使用真实标签。

[0089] 肿瘤表面距离场

[0090] 如图1第一行所示,脊髓肿瘤表现出特别具有挑战性的形状变化。这促使了引入肿瘤表面距离场来学习三维磁共振扫描中肿瘤边界和周围区域的复杂和精细细节。下面结合图5以脊髓肿瘤的二维T1SC切片为例,对肿瘤表面距离场的定义进行介绍。

[0091] 如图5所示,给定一个三维磁共振扫描切片 $t \in \mathbb{R}^{H \times W}$,该切片属于患有任意类型脊髓肿瘤的病人,以及其对应的真实肿瘤掩模 $s \in \{0, 1\}^{H \times W}$,其中1表示前景肿瘤像素,0表示背

景。对于肿瘤掩模内的任何特定像素 p_i ,可以计算其与肿瘤掩模边界的最近距离(带正号),表示为 d_i 。对于肿瘤掩模外的任何特定像素 p_j ,还可以计算其与肿瘤掩模边界的最近距离(带负号),表示为 d_j 。

[0092] 由于脊髓肿瘤通常只占据相对较小的区域,当肿瘤区域外的像素的绝对距离 d_j 大于肿瘤掩模内的最大距离值时,可以选择将距离值截断(truncate)为零。正式定义为:

$$[0093] \quad d'_j \stackrel{\text{truncated}}{\leftarrow} d_j * \mathbb{1}(|d_j| \leq \max\{d_0 \cdots d_i \cdots d_l\}) \quad (5)。$$

[0094] 其中 $\{d_0 \cdots d_i \cdots d_l\}$ 表示肿瘤掩模内的所有距离值, $\mathbb{1}()$ 是指示函数,这种简单的截断将允许网络关注表面边界周围的细节。

[0095] 最后,所有未截断的距离值在 $[0,1]$ 范围内进行归一化,如式(6)和式(7)所示,同时保持所有先前截断的值均为零。

$$[0096] \quad \bar{d}_j = \frac{\left(\frac{d'_j}{\max\{d_0 \cdots d_i \cdots d_l\}} + 1 \right)}{2} \quad (6),$$

$$[0097] \quad \bar{d}_i = \frac{\left(\frac{d_i}{\max\{d_0 \cdots d_i \cdots d_l\}} + 1 \right)}{2} \quad (7)。$$

[0098] 值得注意的是,上述二维切片上的肿瘤表面距离场的定义可以直接扩展至三维MRI。即三维MRI中任意体素的表面距离值是三维空间中该体素距离肿瘤边界的最近距离。

[0099] 类似地,给定一个三维MRI T 及其真实肿瘤掩模 S ,对于三维MRI中的每个体素,可以通过测量到三维肿瘤边界的最近距离来计算其表面距离值,然后进行截断和归一化,获得整个体积的真实肿瘤表面距离值,表示为 \bar{F} ,它将监督新添加的网络分支。值得注意的是,考虑到每类脊髓肿瘤的边界形状往往非常不同,真实表面距离值是按类定义的,而不是以与类无关的方式定义的。

[0100] 损失函数

[0101] 交叉熵损失函数和Dice损失函数:分割分支由交叉熵损失函数和Dice损失函数监督,表示为 l_{ce} 和 l_{dice} ,计算方法分别参见式(2)和式(3)。

[0102] 边界感知损失函数:预测肿瘤表面距离场由边界感知损失函数监督,计算方法参见式(4)。

[0103] 实现

[0104] 所有实验均在单个NVIDIA 3090图形处理器(graphics processing unit,GPU)上进行。模型训练了1000个时期,学习率为0.01,每个时期衰减0.00001。骨干网络nnUNet基于其自动搜索的配置在脊髓肿瘤数据集上进行训练时,包含7层,每层包含两个卷积运算。前两层使用 $1 \times 1 \times 1$ 的内核大小,而后续层使用 $3 \times 3 \times 3$ 的内核大小。第一层的步幅配置为 $1 \times 1 \times 1$,第四层的步幅配置为 $2 \times 2 \times 2$,其余层的步幅配置为 $1 \times 2 \times 2$ 。所有层的特征通道数设置为32、64、128、256、320、320和320。

[0105] 除了使用5折交叉验证评估脊髓肿瘤数据集上的所有模型外,还可以在公共KNIGHT数据集(一种肾脏数据集)上评估所有方法,因为肾脏肿瘤与脊髓肿瘤具有相似性。根据搜索到的配置,在公共KNIGHT数据集上训练主干网络时,该网络包含六层,每层包含两

个 $3 \times 3 \times 3$ 卷积运算。第一层的步幅配置为 $1 \times 1 \times 1$,其余层的步幅配置为 $2 \times 2 \times 2$ 。所有层的特征通道数设置为32、64、128、256、320和320。

[0106] 实验

[0107] 为了验证本申请实施例的方法的有效性,可以将其与其他的肿瘤分割方法进行比较。

[0108] 随着注意力机制和视觉转换器在捕获长距离上下文信息方面的成功,许多工作将基于注意力的方法扩展到基于CNN的框架中,以实现更好的医学分割,包括Trans U-Net、UNETR、Swin UNETR、nnFormer、3D UX-Net以及其他许多变体。最近,大型分割基础模型在自然图像中取得了巨大进步,许多后续工作将它们扩展到医学图像分割领域。得益于强大的网络架构和大型训练数据集,这些方法以大量计算资源和精心快速的工程技巧为代价,表现出色。

[0109] 随着分割模型的发展,专门针对脊髓肿瘤分割的方法也层出不穷。在一个研究中,提出了用于脊索瘤分割的双级联三维CNN。然而,分割的肿瘤位于脊柱区域内,它们显示出不同的强度和尺寸,并与不同的组织类型并列。因此,这种为脊柱设计的分割模型由于固有的差异而不适用于本例中的脊髓肿瘤分割。在另一个研究中,使用由两个U-Net模型组成的两级级联架构来分别定位脊髓和分割肿瘤,但由于其在辨别精细形状方面的弱点,它在确定多种类型的肿瘤方面存在不足。

[0110] 基于此,本例选择与医学图像分割中的以下两组基线进行比较,所有模型都是从头开始训练的。

[0111] 端到端训练基线:包括已建立的最先进的模型nnFormer、3D UX-Net、Swin UNETR和nnUNet。

[0112] 两阶段训练基线:对于每个体素的多类三维分割问题,一个简单的流程是应用每个体素的二类分割(肿瘤和背景),然后是每个体素的分类模型,该模型将带有/不带有预测的二类肿瘤掩模的三维图像作为输入,如图6所示。为了公平比较,在第1阶段,本例中选择相同的骨干nnUNet进行二类分割。在第2阶段,本例中选择了两个强大的模型:3D ResNet101和nnUNet的编码器部分(表示为UEnc),两者后跟具有(1024-512-256-K)个神经元的多层感知器(multilayer perceptron,MLP)层。在第2阶段进行训练时,本例中还会输入带有或不带有估计的类别不可知肿瘤的三维掩模进行比较,表示为模型^{with}_{mask}或

模型^{w/o}_{mask}。

[0113] 综上所述,实验中总共有4个基线:1) nnUNet+ResNet^{with}_{mask}, 2) nnUNet+ResNet^{w/o}_{mask}, 3) nnUNet+UEnc^{with}_{mask}, 4) nnUNet+UEnc^{w/o}_{mask}。

[0114] 指标:遵循心脏分割数据集(Multi-Centre, Multi-Vendor&Multi-Disease Cardiac Image Segmentation Challenge, M&MS Challenge),本例中使用Dice系数和95百分位豪斯多夫距离(Hausdorff Distance, HD)作为指标。对于缺失预测, Hausdorff距离的最大值为450毫米。

[0115] 数据集:如前文所述,除了使用5折交叉验证评估脊髓肿瘤数据集上的所有模型

外,本例还在公共KNIGHT数据集上评估所有方法。该数据集包含400个三维计算机断层(computed tomography,CT)扫描,分为300个扫描的训练集和100个扫描的测试集。每个体素都由两个肿瘤类别之一标注:无辅助治疗(NoAT)和辅助治疗候选(CanAT),或背景类别。所有CT扫描的分辨率都重新缩放为 $2\text{mm} \times 2\text{mm} \times 2\text{mm}$ 。强度是三线性插值的,肿瘤注释是通过最近邻插值的。每个体积的强度都是通过首先从每个体素中减去平均强度值,然后除以扫描的标准偏差来标准化的。

[0116] 脊髓肿瘤数据集上的实验结果

[0117] 表3比较了脊髓肿瘤数据集上所有基线和本申请实施例的方法的定量结果,这些结果取5折交叉验证的平均值。表4-表8中提供了每个部分的详细定量结果。定性结果如图7A-图7D所示。基于表3-表8以及图7A-图7D可以看出:

[0118] -在第一组基线中,nnUNet表现出色,比其他基于注意力的方法获得了更好的Dice分数和Hausdorff距离。

[0119] -在第二组基线中,基于nnUNet编码器的分类器比基于ResNet101的模型获得更高的Dice分数。

[0120] -与所有这些强大的基线相比,本申请实施例的方法在Dice分数和Hausdorff距离方面都取得了明显更好的性能。值得注意的是,与骨干网络nnUNet相比,本申请实施例的方法获得了10%更高的Dice分数和53.1mm更好的Hausdorff距离,证明了本申请中提出的通过边界感知损失学习的肿瘤表面距离场的有效性。

[0121] -还可以注意到的是肿瘤类型星形细胞瘤的Dice分数(35.2%)明显低于其他类型。一个关键原因是星形细胞瘤和室管膜瘤的外观相似,导致这两种肿瘤类型之间经常被错误分类。因此,室管膜瘤的Dice分数也相对较低(57.8%)。

[0122] 表3脊髓肿瘤数据集上使用5折交叉验证的Dice分数(%)和Hausdorff距离(mm)

方法	脊膜瘤		室管膜瘤		星形细胞瘤		血管母细胞瘤		平均值	
	Dice	HD	Dice	HD	Dice	HD	Dice	HD	Dice	HD
nnFormer	37.1	202.4	0.0	450.0	0.0	450.0	0.0	450.0	9.3	388.1
3D UX-Net	40.3	229.1	22.1	299.0	8.1	361.7	28.8	286.9	24.8	294.2
Swin UNETR	41.3	220.7	20.7	305.0	7.3	370.2	26.7	301.4	24.0	299.3
nnUNet	74.0	69.1	43.5	195.3	26.0	270.1	67.7	111.0	52.8	161.4
[0123] nnUNet+										
ResNet ^{with} _{mask}	33.4	288.2	3.9	428.2	0.16	446.7	0.0	450.0	9.4	403.3
nnUNet+										
ResNet ^{w/o} _{mask}	26.7	318.0	7.5	408.7	0.0	450.0	0.0	450.0	8.6	406.7
nnUNet+										
UEnc ^{with} _{mask}	66.9	128.1	37.7	241.8	28.1	303.8	57.6	168.8	47.6	210.6
nnUNet+										
UEnc ^{w/o} _{mask}	53.7	184.6	25.2	309.7	11.3	397.4	14.0	384.8	26.1	319.1
所提方法	80.9	34.4	57.8	117.3	35.2	205.2	74.6	76.1	62.1	108.3

[0124] 表4脊髓肿瘤数据集Fold1上的Dice分数(%)和Hausdorff距离(mm)

方法	脊膜瘤		室管膜瘤		星形细胞瘤		血管母细胞瘤		平均值		
	Dice	HD	Dice	HD	Dice	HD	Dice	HD	Dice	HD	
[0125]	nnFormer	35.6	230.1	0.0	450.0	0.0	450.0	0.0	450.0	8.9	395.0
	3D UX-Net	37.3	253.0	21.6	317.4	7.9	354.5	27.7	269.5	23.6	298.6
	Swin UNETR	48.8	167.6	21.3	303.2	10.0	363.3	29.8	298.2	27.5	283.1
	nnUNet	73.4	56.2	46.4	167.4	21.9	299.5	51.9	189.3	48.4	178.1
nnUNet+ ResNet _{with mask}	34.0	280.0	0.0	450.0	0.0	450.0	0.0	450.0	8.5	407.5	
[0126]	nnUNet+ ResNet _{w/o mask}	34.3	271.9	0.0	450.0	0.0	450.0	0.0	450.0	8.6	405.5
	nnUNet+ UEnc _{with mask}	62.3	140.7	41.5	215.4	35.6	287.1	54.4	189.6	48.5	208.2
	nnUNet+ UEnc _{w/o mask}	47.9	203.0	25.5	304.2	17.0	381.5	6.5	416.8	24.2	326.4
	所提方法	78.4	40.4	54.7	151.2	30.6	206.6	76.3	80.6	60.0	119.7

[0127] 表5脊髓肿瘤数据集Fold2上的Dice分数(%)和Hausdorff距离(mm)

方法	脊膜瘤		室管膜瘤		星形细胞瘤		血管母细胞瘤		平均值		
	Dice	HD	Dice	HD	Dice	HD	Dice	HD	Dice	HD	
[0128]	nnFormer	37.2	193.3	0.0	450.0	0.0	450.0	0.0	450.0	9.3	385.8
	3D UX-Net	41.4	236.7	14.1	350.8	9.0	348.8	36.9	241.0	25.4	294.3
	Swin UNETR	39.0	236.6	12.2	347.0	10.6	366.7	24.7	310.2	21.6	315.1
	nnUNet	72.9	83.7	33.0	255.2	32.6	206.0	64.8	119.2	50.8	166.0
nnUNet+ ResNet _{with mask}	33.9	280.1	0.0	450.0	0.0	450.0	0.0	450.0	8.5	407.5	
nnUNet+ ResNet _{w/o mask}	33.3	288.4	0.0	450.0	0.0	450.0	0.0	450.0	8.3	409.6	
nnUNet+ UEnc _{with mask}	72.1	93.4	21.3	317.5	33.0	258.0	69.8	123.2	49.1	198.0	
nnUNet+ UEnc _{w/o mask}	62.9	146.5	22.7	328.3	24.0	319.8	3.5	432.7	28.3	306.8	
所提方法	82.2	35.0	59.5	92.6	41.8	153.7	72.7	77.3	64.1	89.7	

[0129] 表6脊髓肿瘤数据集Fold3上的Dice分数(%)和Hausdorff距离(mm)

方法	脊膜瘤		室管膜瘤		星形细胞瘤		血管母细胞瘤		平均值		
	Dice	HD	Dice	HD	Dice	HD	Dice	HD	Dice	HD	
[0130]	nnFormer	22.3	274.0	0.0	450.0	0.0	450.0	0.0	450.0	5.6	406.0
	3D UX-Net	42.4	222.2	23.6	287.0	10.3	341.1	30.6	266.4	26.7	279.2
	Swin UNETR	44.3	207.3	24.2	268.0	8.2	357.1	27.7	292.9	26.1	281.3
	nnUNet	78.9	60.1	47.1	156.2	35.1	212.3	80.7	34.9	60.5	115.9
nnUNet+ ResNet _{with mask}	29.0	313.3	3.6	430.7	0.0	450.0	0.0	450.0	8.2	411.0	
nnUNet+ ResNet _{w/o mask}	25.6	329.8	12.3	383.4	0.0	450.0	0.0	450.0	9.5	403.3	
nnUNet+ UEnc _{with mask}	68.7	120.0	40.7	228.9	15.0	366.4	39.5	248.6	41.0	241.0	
nnUNet+ UEnc _{w/o mask}	60.7	164.8	25.7	306.3	0.0	450.0	27.8	322.6	28.6	310.9	
[0131]	所提方法	86.2	23.1	55.2	122.1	43.7	161.5	76.9	37.0	65.5	85.9

[0132] 表7脊髓肿瘤数据集Fold4上的Dice分数(%)和Hausdorff距离(mm)

方法	脊膜瘤		室管膜瘤		星形细胞瘤		血管母细胞瘤		平均值	
	Dice	HD	Dice	HD	Dice	HD	Dice	HD	Dice	HD
nnFormer	53.3	107.4	0.0	450.0	0.0	450.0	0.0	450.0	13.3	364.4
3D UX-Net	43.3	192.7	21.1	297.3	6.9	387.3	20.2	345.5	22.9	305.7
Swin UNETR	36.6	255.3	16.9	347.2	2.2	404.8	15.5	363.1	17.8	342.6
nnUNet	71.0	78.7	40.7	214.1	23.3	310.7	70.5	85.5	51.4	172.3
nnUNet+										
ResNet ^{with mask}	36.4	283.0	0.0	450.0	0.0	450.0	0.0	450.0	9.1	408.3
nnUNet+										
ResNet ^{w/o mask}	12.8	386.4	23.3	322.7	0.0	450.0	0.0	450.0	9.0	402.3
nnUNet+										
UEnc ^{with mask}	62.4	171.3	42.5	228.9	34.0	289.6	54.1	167.2	48.3	214.3
nnUNet+										
UEnc ^{w/o mask}	48.7	203.3	18.1	345.9	15.7	385.5	22.8	344.0	26.3	319.7
所提方法	79.0	39.4	53.1	139.0	31.4	258.0	76.8	74.6	60.1	127.7

[0134] 表8脊髓肿瘤数据集Fold5上的Dice分数(%)和Hausdorff距离(mm)

方法	脊膜瘤		室管膜瘤		星形细胞瘤		血管母细胞瘤		平均值	
	Dice	HD	Dice	HD	Dice	HD	Dice	HD	Dice	HD
nnFormer	37.0	207.3	0.0	450.0	0.0	450.0	0.0	450.0	9.3	389.3
3D UX-Net	36.9	240.7	30.3	242.6	6.6	376.9	28.8	312.1	25.7	293.1
Swin UNETR	37.6	236.7	29.1	259.4	5.6	359.2	35.8	242.7	27.0	274.5
nnUNet	73.6	66.9	50.3	183.4	17.3	321.9	70.7	126.1	53.0	174.6
nnUNet+										
ResNet ^{with mask}	33.9	284.8	15.9	360.3	0.8	433.3	0.0	450.0	12.7	382.1
nnUNet+										
ResNet ^{w/o mask}	27.5	313.7	2.1	437.4	0.0	450.0	0.0	450.0	7.4	412.8
nnUNet+										
UEnc ^{with mask}	68.9	115.1	42.6	218.6	22.8	318.1	70.4	115.3	51.2	191.7
nnUNet+										
UEnc ^{w/o mask}	48.5	205.3	34.0	263.6	0.0	450.0	9.2	407.7	22.9	331.7
所提方法	78.8	34.1	66.7	81.4	28.4	246.2	70.3	111.2	61.1	118.2

[0136] KNIGHT数据集上的结果

[0137] 表9比较了所有方法在KNIGHT数据集上的定量结果,定性结果如图7A-图7D所示。基于表9和图7A-图7D可以得到:

[0138] -在两组基线中,虽然nnUNet和nnUNet+ResNet^{with mask}表现出色,但本申请实施例的方法超越了它们,实现了40.7%的Dice分数和226.8mm的Hausdorff距离。

[0139] -还可以注意到,大多数两阶段方法倾向于将所有受试者归类为“**NoAT**”类别。因此,它们在“**NoAT**”类中表现出高性能,但在“**CanAT**”类中产生接近零的Dice分数。

[0140] 在两个数据集上,如图7A-图7D所示,本申请实施例的方法预测的肿瘤边界与基本事实显示出更大的一致性。相比之下,其他基线经常预测更大的肿瘤,导致大量假阳性体素。此外,一些基线倾向于预测具有不同肿瘤类型的多个子区域,而本申请实施例的方法始终如一地生成具有精细边界和正确肿瘤类型的更准确的掩模。

[0141] 表9KNIGHT数据集的Dice分数(%)和Hausdorff距离(mm)

消融实验	NoAT		CanAT		平均值	
	Dice	HD	Dice	HD	Dice	HD
nnFormer	20.7	238.3	13.5	332.4	17.1	285.3
3D UX-Net	33.7	192.9	14.5	343.0	24.1	267.9
Swin UNETR	31.9	211.4	17.3	328.7	24.6	270.0
[0142] nnUNet	46.8	177.3	20.9	320.2	33.8	248.7
nnUNet+ResNet _{mask} ^{with}	44.4	204.8	34.0	290.9	39.2	247.9
nnUNet+ResNet _{mask} ^{w/o}	23.0	330.3	22.6	337.0	22.8	333.6
nnUNet+UEnc _{mask} ^{with}	50.5	178.4	0.0	450.0	25.2	314.2
nnUNet+UEnc _{mask} ^{w/o}	50.5	178.4	0.0	450.0	25.2	314.2
所提方法	48.0	181.9	33.4	271.8	40.7	226.8

[0143] 消融实验

[0144] 为了验证本申请实施例设计的有效性,本例在公共KNIGHT数据集上进行了以下几组消融研究。

[0145] -第1组:为了验证对肿瘤表面距离场的设计,本例选择了四种不同的设置:1)距离场既不截断也不归一化;2)距离场被截断,但未归一化;3)距离场被截断和归一化,这是本申请实施例的方法的设置;4)边界感知损失 l_{ba} 中的 l_1 项即 $|f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}|$ 被 l_2 项即 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$ 取代;5)边界感知损失 l_{ba} 中的 l_1 项即 $|f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}|$ 被交叉熵损失 l_{ce} 取代。

[0146] -第2组:对于公式(5)中定义的截断策略,本例验证了三种设置:距离 d_j 分别在 $\max\{d_0 \cdots d_i \cdots d_1\}$ 的一倍/两倍/三倍处被截断。直观地看,截断范围越广,需要聚焦的区域就越大,因此可能效率较低。

[0147] -第3组:本例进一步验证了多类距离场的设计。为了进行比较,本例将多类感知简化为与类无关的距离场。这意味着图4中的表面距离场分支具有 $\mathbb{R}^{H \times W \times D \times 1}$ 的输出形状。

[0148] -第4组:对于公式(1)中定义的边界感知损失,本例验证了 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$ 这一项的有效性。

[0149] 表10-表13分别比较了1/2/3/4组的消融实验结果,图8显示了定性结果。基于表10-表13以及图8可以得到:

[0150] -在表10中,本申请实施例的截断设计将Dice得分提高了5.9%,而对截断距离场进行归一化进一步将Dice得分提高了9.5%。尽管如此,基于 l_1 的 l_{ba} 的使用仅比基于 l_{ce} 的或 e_2 的略好一些。

[0151] -在表11中,要截断的区域越宽,获得的结果越差。原因是肿瘤边界附近的精细细节可能比远离边界的像素更重要。

[0152] -在表12中,本申请实施例中的多类距离场简化了复杂边界的学习,从而提供了对不同肿瘤类型的更清晰的理解,使Dice得分比类无关设置提高了4.3%。

[0153] -在表13中, $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$ 项驱动模型更多地关注具有非零距离值的体素,例如感兴趣的肿瘤边界区域的体素,这使Dice得分提高了1%。如果停止训练过程中 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$ 的梯度计算,则Dice得分降低了2%。

[0154] 表10第1组在KNIGHT数据集上的消融实验

消融实验	NoAT		CanAT		平均值	
	Dice	HD	Dice	HD	Dice	HD
距离场 (无截断, 无归一化, l_{ba} 基于 l_1)	29.5	257.3	21.0	322.4	25.3	289.8
距离场 (有截断, 无归一化, l_{ba} 基于 l_1)	44.6	176.3	17.8	328.4	31.2	252.4
距离场 (有截断, 有归一化, l_{ba} 基于 l_1)	48.0	181.9	33.4	271.8	40.7	226.8
距离场 (有截断, 有归一化, l_{ba} 基于 l_2)	50.6	165.4	26.9	292.5	38.7	229.0
距离场 (有截断, 有归一化, l_{ba} 基于 l_{ce})	49.6	162.7	30.2	293.1	39.9	227.9

[0156] 表11第2组在KNIGHT数据集上的消融实验

消融实验	NoAT		CanAT		平均值	
	Dice	HD	Dice	HD	Dice	HD
截断 1* $\max\{d_0 \dots d_i \dots d_l\}$	48.0	181.9	33.4	271.8	40.7	226.8
截断 2* $\max\{d_0 \dots d_i \dots d_l\}$	47.7	173.2	25.4	312.5	36.5	242.8
截断 3* $\max\{d_0 \dots d_i \dots d_l\}$	49.5	171.5	26.3	300.5	37.9	236.0

[0159] 表12第3组在KNIGHT数据集上的消融实验

消融实验	NoAT		CanAT		平均值	
	Dice	HD	Dice	HD	Dice	HD
类别无关距离场	48.6	174.7	24.3	313.7	36.4	244.2
多类别距离场	48.0	181.9	33.4	271.8	40.7	226.8

[0161] 表13第4组在KNIGHT数据集上的消融实验

	消融实验	NoAT		CanAT		平均值	
		Dice	HD	Dice	HD	Dice	HD
[0162]	边界感知损失：无 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$	48.9	164.1	30.4	290.1	39.7	227.1
	边界感知损失：有 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$	48.0	181.9	33.4	271.8	40.7	226.8
	边界感知损失：训练过程中停止 $(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2$ 的梯度计算	48.7	177.2	28.1	297.3	38.4	237.2

[0163] 基于上述实验,可以确定本申请实施例的方法具有较高的分割精度,在脊髓肿瘤数据集和公共肾肿瘤分割数据集上

[0164] 都明显优于现有基线。

[0165] 上面对本申请实施例提供的方法进行了详细介绍,下面结合附图对本申请实施例提供的装置进行详细介绍。

[0166] 参见图9,为本申请实施例提供的一种肿瘤诊断设备的结构示意图。如图9所示的肿瘤诊断设备900,可包括获取模块910和分割模块920。

[0167] 其中,获取模块910用于获取多位肿瘤病患的三维MRI作为肿瘤数据集,三维MRI包括钆增强的T1SC切片;

[0168] 分割模块920用于将肿瘤数据集中的三维MRI作为第一分割模型的输入进行肿瘤分割,得到三维MRI中肿瘤的分类标签;

[0169] 其中,第一分割模型为基于卷积神经网络CNN的模型,第一分割模型中包括第一模型分支和第二模型分支,第一模型分支用于预测类别标签,第二模型分支用于基于边界感知预测肿瘤的表面距离场,表面距离场用于描述三维MRI中每个体素到肿瘤表面的最近距离,第一分割模型的训练和优化基于第一模型分支和第二模型分支的训练和优化进行。

[0170] 可选的,第二模型分支基于第一边界感知损失函数训练和优化,第一边界感知损失函数用于确定三维MRI中每个体素的边界感知损失,每个体素的边界感知损失基于每个体素的表面距离值确定,表面距离值用于表示每个体素到肿瘤表面的最近距离。

[0171] 可选的,体素包括肿瘤外部的体素和肿瘤内部的体素,肿瘤外部的体素的表面距离值表示为负值,肿瘤内部的体素的表面距离值表示为正值。

[0172] 可选的,若肿瘤外部的体素的表面距离值的绝对值大于肿瘤内部的体素的表面距离值,则表面距离值计为0。

[0173] 可选的,每个体素的边界感知损失基于每个体素的表面距离值归一化后的值确定。

[0174] 可选的,第二模型分支的训练和优化按照肿瘤的分类进行。

[0175] 可选的,第一边界感知损失函数表示为下式:

$$[0176] \quad \ell_{ba} = -(f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)})^2 * |f_{(h,w,d,k)} - \bar{f}_{(h,w,d,k)}|,$$

[0177] 其中, l_{ba} 用于表示边界感知损失, h 用于表示三维MRI的横向像素点数, w 用于表示三维MRI的纵向像素点数, d 用于表示三维MRI的切片数量, k 用于表示三维MRI的类别总数, $f_{(h,w,d,k)}$ 用于表示第二模型分支预测的第 (h,w,d,k) 个体素的表面距离值, $\bar{f}_{(h,w,d,k)}$ 用于表示第 (h,w,d,k) 个体素的真实表面距离值。

[0178] 可选的, 第二模型分支基于三维MRI中的所有体素的边界感知损失的平均值训练和优化。

[0179] 可选的, 第一模型分支基于第一分割损失函数训练和优化, 第一分割损失函数包括交叉熵损失函数和骰子损失函数。

[0180] 本申请实施例还提供了一种电子设备。如图10所示, 该电子设备1000包括: 至少一个处理器1001、存储器1002以及存储在该存储器1002中并可在该至少一个处理器1001上运行的计算机程序1003, 该处理器1001执行计算机程序1003时实现本申请提供的方法。

[0181] 示例性的, 计算机程序1003可以被分割成一个或多个模块/单元, 一个或者多个模块/单元被存储在存储器1002中, 并由处理器1001执行, 以完成本申请。一个或多个模块/单元可以是能够完成特定功能的一系列计算机程序指令段, 该指令段用于描述计算机程序在电子设备1000中的执行过程。

[0182] 本领域技术人员可以理解, 图10仅仅是电子设备1000的示例, 并不构成对电子设备的限定, 可以包括比图示更多或更少的部件, 或者组合某些部件, 或者不同的部件, 例如电子设备1000还可以包括输入输出设备、网络接入设备、总线等。

[0183] 处理器1001可以是中央处理单元 (central processing unit, CPU), 还可以是其它通用处理器、数字信号处理器 (digital signal processor, DSP)、专用集成电路 (接入点 application specific integrated circuit, ASIC)、现场可编程门阵列 (field-programmable gate array, FPGA) 或者其它可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等。

[0184] 存储器1002可以是电子设备1000的内部存储单元, 例如电子设备1000的硬盘或内存。存储器1002也可以是电子设备1000的外部存储设备, 例如电子设备1000上配备的插接式硬盘, 智能存储卡 (smart media card, SMC), 安全数字 (secure digital, SD) 卡, 闪存卡 (flash card) 等。进一步地, 存储器1002还可以既包括电子设备1000的内部存储单元也包括外部存储设备。存储器1002用于存储计算机程序以及电子设备1000所需的其它程序和数据。存储器1002还可以用于暂时地存储已经输出或者将要输出的数据。

[0185] 本实施例提供的电子设备1000可以执行上述方法实施例, 其实现原理与技术效果类似, 此处不再赘述。

[0186] 本申请实施例还提供了一种计算机可读存储介质, 该计算机可读存储介质存储有计算机程序, 该计算机程序被处理器执行时可实现上述各个方法实施例中的步骤。

[0187] 本申请实施例提供了一种计算机程序产品, 当计算机程序产品在电子设备上运行时, 使得电子设备执行时实现可实现上述各个方法实施例中的步骤。

[0188] 集成的单元如果以软件功能单元的形式实现并作为独立的产品销售或使用时, 可以存储在一个计算机可读存储介质中。基于这样的理解, 本申请实现上述方法实施例中的全部或部分流程, 可以通过计算机程序来指令相关的硬件来完成, 该计算机程序可存储

于一计算机可读存储介质中,该计算机程序在被处理器执行时,可实现上述各个方法实施例的步骤。其中,该计算机程序包括计算机程序代码,该计算机程序代码可以为源代码形式、对象代码形式、可执行文件或某些中间形式等。该计算机可读介质至少可以包括:能够将计算机程序代码携带到拍照装置/电子设备的任何实体或装置、记录介质、计算机存储器、ROM(read-only memory,只读存储器)、RAM(random access memory,随机存取存储器)、CD-ROM(compact disc read-only memory,只读光盘)、磁带、软盘和光数据存储设备等。本申请提到的计算机可读存储介质可以为非易失性存储介质,换句话说,可以是非瞬时性存储介质。

[0189] 在上述实施例中,对各个实施例的描述都各有侧重,某个实施例中未详述或记载的部分,可以参见其它实施例的相关描述。

[0190] 本领域普通技术人员可以意识到,结合本文中所公开的实施例描述的各示例的单元及算法步骤,能够以电子硬件、或者计算机软件和电子硬件的结合来实现。这些功能究竟以硬件还是软件方式来执行,取决于技术方案的特定应用和设计约束条件。专业技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能,但是这种实现不应认为超出本申请的范围。

[0191] 在本申请所提供的实施例中,应该理解到,所揭露的装置/设备和方法,可以通过其它的方式实现。例如,以上所描述的装置/设备实施例仅仅是示意性的,例如,模块或单元的划分,仅仅为一种逻辑功能划分,实际实现时可以有另外的划分方式,例如多个单元或组件可以结合或者可以集成到另一个系统,或一些特征可以忽略,或不执行。另一点,所显示或讨论的相互之间的耦合或直接耦合或通讯连接可以是通过一些接口,装置或单元的间接耦合或通讯连接,可以是电性,机械或其它的形式。

[0192] 应当理解,当在本申请说明书和所附权利要求书中使用时,术语“包括”指示所描述特征、整体、步骤、操作、元素和/或组件的存在,但并不排除一个或多个其它特征、整体、步骤、操作、元素、组件和/或其集合的存在或添加。

[0193] 还应当理解,在本申请说明书和所附权利要求书中使用的术语“和/或”是指相关联列出的项中的一个或多个的任何组合以及所有可能组合,并且包括这些组合。

[0194] 如在本申请说明书和所附权利要求书中所使用的那样,术语“如果”可以依据上下文被解释为“当...时”或“一旦”或“响应于确定”或“响应于检测到”。类似地,短语“如果确定”或“如果检测到[所描述条件或事件]”可以依据上下文被解释为意指“一旦确定”或“响应于确定”或“一旦检测到[所描述条件或事件]”或“响应于检测到[所描述条件或事件]”。

[0195] 另外,在本申请说明书和所附权利要求书的描述中,术语“第一”、“第二”等仅用于区分描述,而不能理解为指示或暗示相对重要性。

[0196] 最后应说明的是:以上各实施例仅用以说明本申请的技术方案,而非对其限制;尽管参照前述各实施例对本申请进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分或者全部技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本申请各实施例技术方案的范围。




图1

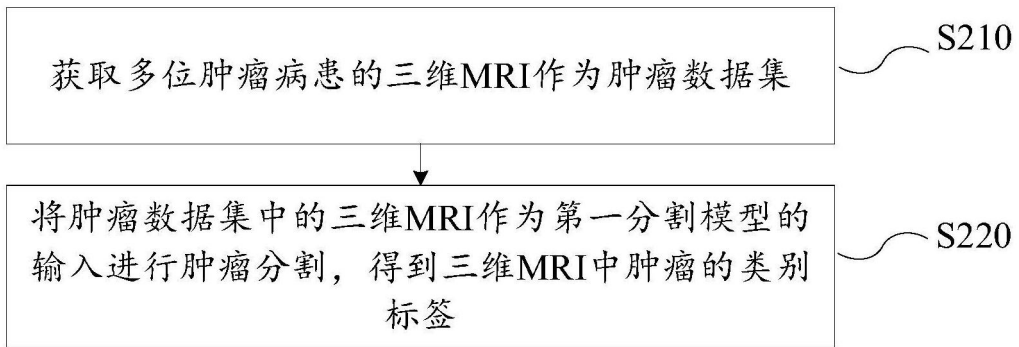


图2




图3




图4





图5

第一阶段：二类肿瘤分割



第二阶段：多类肿瘤分割

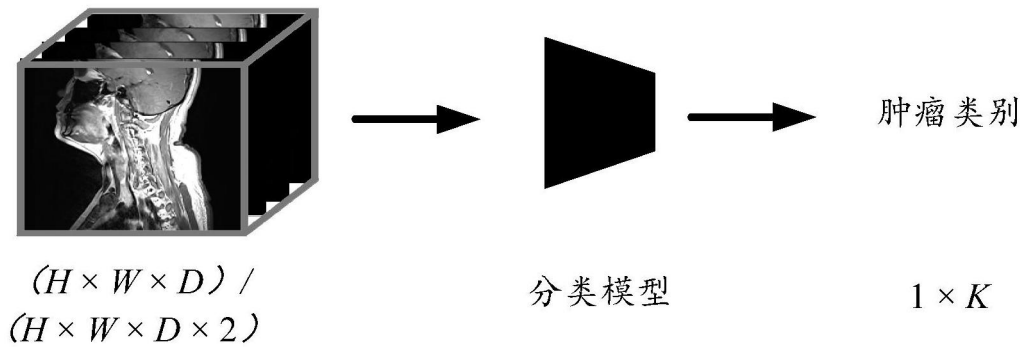


图6

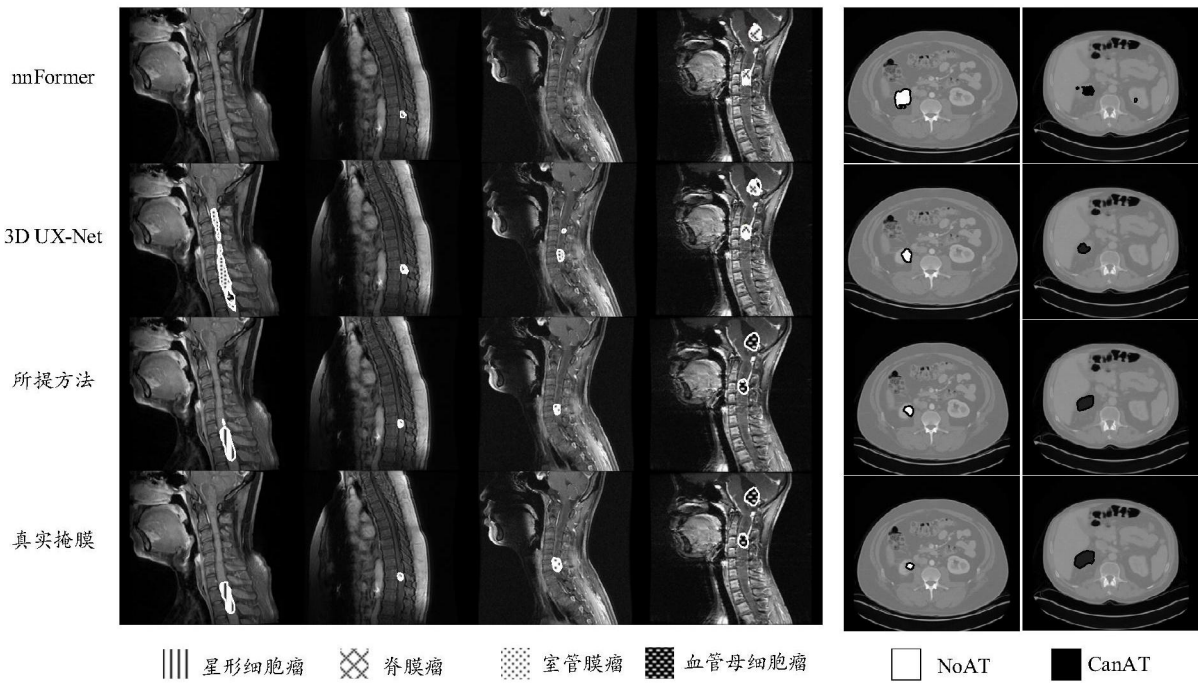


图7A




图7B




图7C




图7D

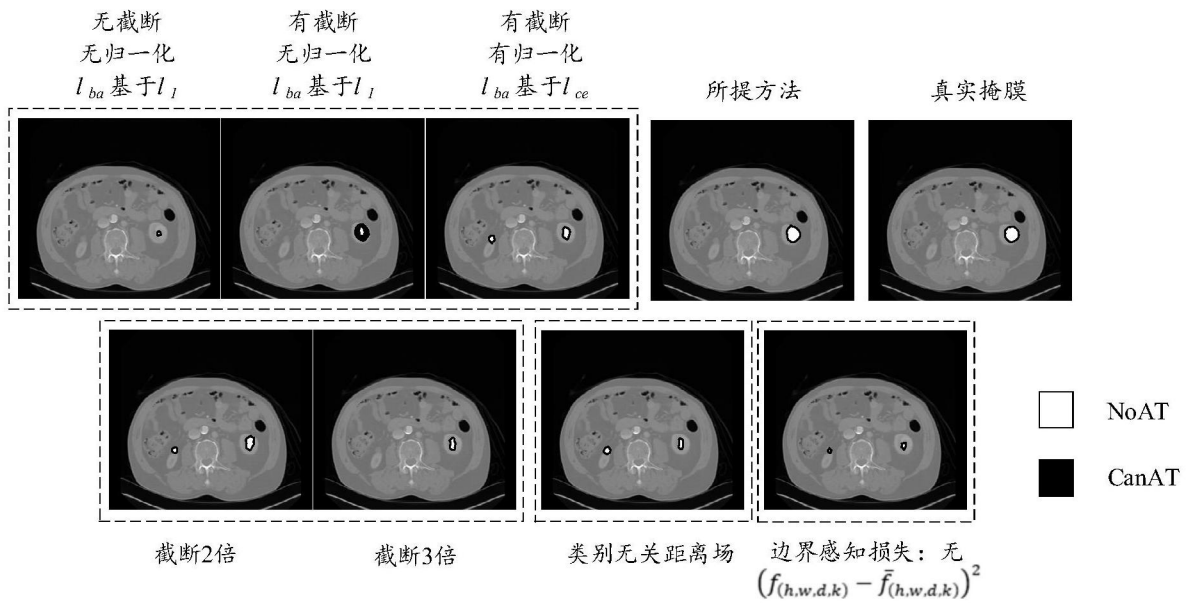


图8



图9

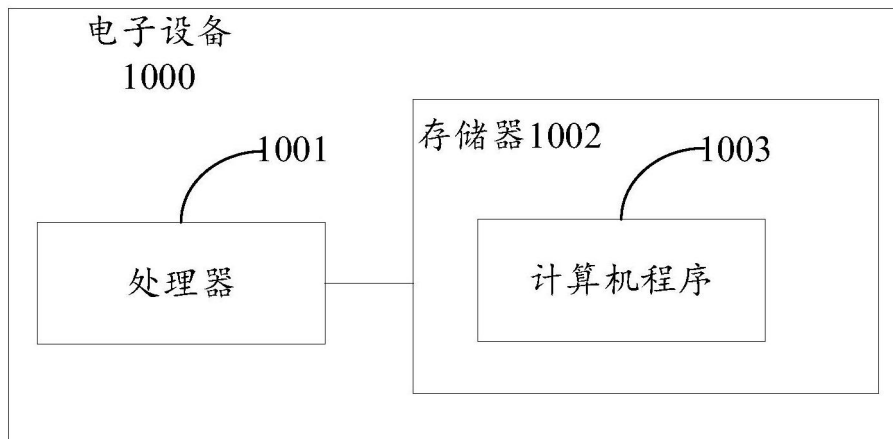


图10